



Flächennutzungsmonitoring V Methodik – Analyseergebnisse – Flächenmanagement

IÖR Schriften Band 61 · 2013

ISBN: 978-3-944101-18-7

Automatische Erkennung von Gebäudetypen auf Grundlage von Geobasisdaten

Robert Hecht

Hecht, R. (2013): Automatische Erkennung von Gebäudetypen auf Grundlage von Geobasisdaten. In: Meinel, G.; Schumacher, U.; Behnisch, M. (Hrsg.): Flächennutzungsmonitoring V. Methodik – Analyseergebnisse – Flächenmanagement. Berlin: Rhombos, IÖR Schriften 61, S. 199-210.

Automatische Erkennung von Gebäudetypen auf Grundlage von Geobasisdaten

Robert Hecht

Zusammenfassung

Für die kleinräumige Modellierung und Analyse von Prozessen im Siedlungsraum spielen gebäudebasierte Informationen eine zentrale Rolle. In amtlichen Geodaten, Karten und Diensten des Liegenschaftskatasters und der Landesvermessung werden die Gebäude in ihrem Grundriss modelliert. Semantische Informationen zur Gebäudefunktion, der Wohnform oder dem Baualter sind in den Geobasisdaten nur selten gegeben.

In diesem Beitrag wird eine Methode zur automatischen Klassifizierung von Gebäudegrundrissen vorgestellt mit dem Ziel, diese für die Ableitung kleinräumiger Informationen zur Siedlungsstruktur zu nutzen. Dabei kommen Methoden der Mustererkennung und des maschinellen Lernens zum Einsatz. Im Kern werden Gebäudetypologie, Eingangsdaten, Merkmalsgewinnung sowie verschiedene Klassifikationsverfahren hinsichtlich ihrer Genauigkeit und Generalisierungsfähigkeit untersucht. Der Ensemble-basierte Random-Forest-Algorithmus zeigt im Vergleich zu 15 weiteren Lernverfahren die höchste Generalisierungsfähigkeit und Effizienz und wurde als bester Klassifikator zur Lösung der Aufgabenstellung identifiziert.

Für Gebäudegrundrisse im Vektormodell, speziell den Gebäuden aus der ALK, dem ALKIS® oder dem ATKIS® Basis-DLM sowie den amtlichen Hausumringen und 3D-Gebäudemodellen, kann mit dem Klassifikator für alle städtischen Gebiete eine Klassifikationsgenauigkeit zwischen 90 % und 95 % erreicht werden. Die Genauigkeit bei Nutzung von Gebäudegrundrissen extrahiert aus digitalen topographischen Rasterkarten ist mit 76 % bis 88 % deutlich geringer.

Die automatische Klassifizierung von Gebäudegrundrissen leistet einen wichtigen Beitrag zur Gewinnung von Informationen für die kleinräumige Beschreibung der Siedlungsstruktur. Neben der Relevanz in den Forschungs- und Anwendungsfeldern der Stadtgeographie und Stadtplanung sind die Ergebnisse auch für die kartographischen Arbeitsfelder der Kartengeneralisierung, der automatisierten Kartenerstellung sowie verschiedenen Arbeitsfeldern der Geovisualisierung relevant.

1 Einführung

Für die Beantwortung wissenschaftlicher und planerischer Fragestellungen im Siedlungsraum werden kleinräumige Informationen zur funktionalen, morphologischen

und sozioökonomischen Siedlungsstruktur benötigt. Gebäude spielen dabei eine zentrale Rolle, da sie die physische Struktur der Stadt prägen und sich durch deren Nutzung Verteilungsmuster von Wohnungen, Arbeitsstätten und Infrastrukturen ergeben.

Trotz großer Bedeutung stehen der Wissenschaft und Praxis nur wenig aktuelle, oftmals nur räumlich stark aggregierte Informationen zur Siedlungsstruktur (insb. Gebäudestruktur, Bebauungsdichte, Geschossfläche, Wohnung- und Einwohnerzahl, Baualter, bauliche Aktivität) zu Verfügung (vgl. Behnisch et al. 2012). So ist die kleinste räumliche Bezugseinheit der amtlichen Flächen- und Gebäudestatistik in Deutschland die Gemeindeebene, weshalb diese Daten lediglich für regionale oder überregionale Fragenstellungen mit geringem Anspruch auf räumliche Detailliertheit geeignet sind. Zwar bieten einige kommunale Informationssysteme ein breites thematisches Spektrum von Informationen auf kleinräumiger Ebene an. Fehlende Flächendeckung, der schwierige Zugang und die äußerst große Heterogenität machen die Daten jedoch unattraktiv für kommunalübergreifende Analysen (Haußmann 2012). Kleinräumige Daten kommerzieller Anbieter bieten durchaus flächendeckende Informationen an. Deren Datenaufbereitungsprozesse sind jedoch sehr intransparent und der Erwerb mit hohen Datenkosten verbunden.

Eine Möglichkeit an kleinteilige Informationen zur Siedlungsstruktur zu gelangen ist es, diese mithilfe räumlicher Analysen im GIS abzuschätzen (u. a. Meinel et al. 2008; Geiß et al. 2011). Grundlage dafür ist ein zweckmäßig klassifiziertes Gebäudemodell. Die Frage stellt sich dabei, wie man an dieses zweckmäßig klassifizierte Gebäudemodell gelangt. Gebäude werden zwar im Liegenschaftskataster und in topographisch-kartographischen Informationssystemen der Landesvermessung geführt und in Form von Geodaten, Karten und Diensten angeboten. Der erfasste Gebäudegrundriss besitzt allerdings nur selten explizite semantische Informationen zur Gebäudefunktion, der Wohnform, dem Baualter oder der Geschosshöhe. Bundesweit einheitliche Festlegungen der Arbeitsgemeinschaft der Vermessungsverwaltungen der Länder (AdV) sehen im ALKIS (Liegenschaftskataster) lediglich eine funktionale Unterscheidung von „Wohngebäude“, „Gebäude für öffentliche Zwecke“ und „Gebäude für Wirtschaft oder Gewerbe“ zwingend vor (AdV 2008). Die amtlichen Hausumringe und Hauskoordinaten besitzen hingegen gar keine attributive Beschreibung zum Gebäude (Westenberg, Will 2013).

Die manuelle Kartierung von Gebäudetypen ist ein sehr zeitaufwändiger Prozess, der häufig auch durch subjektive Einflüsse geprägt ist. Computertechnologie und Methoden der Bildanalyse, Mustererkennung und des Bildverstehens erlauben es, Objekte und Muster automatisch in Bildern oder Vektordaten zu erkennen und zu klassifizieren. Es stellt sich deshalb die Frage, ob es möglich ist, Gebäudetypen automatisch in Geobasisdaten zu erkennen, um diese für die Ableitung kleinräumiger Informationen zur Siedlungsstruktur zu nutzen. Im vorliegenden Beitrag soll ein Einblick in die wichtigsten Erkenntnisse der Dissertation von Hecht (2013) gegeben werden, die sich dieser

Frage stellt. Ziel der Arbeit war die Entwicklung methodischer Beiträge zur automatischen Klassifizierung von Gebäudegrundrissen für die kleinräumige Beschreibung der Siedlungsstruktur unter Nutzung von Methoden der Bildanalyse, Geoinformatik und des maschinellen Lernens einschließlich der Validierung und Bewertung anhand verschiedener Eingangsdatentypen.

2 Forschungsstand und Ziel

Erste Ansätze zur Klassifizierung urbaner Strukturen gehen auf die bildbasierte Auswertung von Fernerkundungsdaten zurück (Wharton 1982; Barnsley, Barr 1996; Gong, Howarth 1992). Erst mit der Verfügbarkeit digitaler, hochauflösender Bild- und Vektordaten gewann die Klassifizierung individueller Gebäudegrundrisse in den letzten Jahren an Bedeutung und ist ein relativ junges Forschungsthema.

Die bisherigen Ansätze unterscheiden sich je nach Zweck und Forschungsgebiet in der Gebäudetypologie (Kriterien, Klassenanzahl), den verwendeten Eingangsdaten (u. a. topographische Vektordaten, sehr hochauflösende Satellitenbilddaten, LiDAR-Daten) und dem gewählten Klassifikationsansatz. Prinzipiell stehen wissensbasierte Ansätze (top-down) den datengetriebenen Ansätzen (bottom-up) gegenüber (vgl. Lüscher et al. 2009). Von wissensbasierten Ansätzen spricht man, wenn das Wissen über die Objekte aus Regelwerken, Handbüchern oder Expertenbeschreibungen abgeleitet und in einem Modell vom Menschen explizit bereitgestellt wird. Das Modell versteht sich dann als Zuordnungsvorschrift (Klassifikator), in dem ein Gebäudegrundriss über eine Regel genau einer Klasse zugeordnet wird, wie etwa in den Arbeiten von Orford & Radcliffe (2007), Meinel et al. (2009) oder Smith, Crooks (2010). Eine derartige Herangehensweise führt zwar zu einer hohen Transparenz und Nachvollziehbarkeit, diese ist jedoch nur bei leicht formalisierbaren Erkennungsproblemen mit eindeutig beschreibbaren Gebäudetypen realisierbar. Bei den datengetriebenen Verfahren erfolgt der wesentliche Teil der Modellbildung automatisch anhand einer gegebenen Trainingsdatenmenge unter Nutzung von Methoden der Mustererkennung (engl. pattern recognition) und des maschinellen Lernens (engl. machine learning). Mit zunehmender Komplexität einer Klassifizierung und größeren Anforderungen an die semantische Auflösung gewinnen die datengetriebenen Verfahren immer mehr an Bedeutung, die je nach Lernstrategie weiter nach überwachten (u. a. Steiniger et al. 2008; Römer, Plümer 2010; Henn et al. 2012) und unüberwachten Ansätzen (u. a. Neidhart, Sester 2004; Werder et al. 2010; Geiß et al. 2011) unterschieden werden können.

Der aktuelle Forschungsstand legt offen, dass mit den bisherigen Ansätzen nur eine geringe Anzahl an Klassen und Merkmalen berücksichtigt werden, diese an vergleichsweise kleinen Untersuchungsgebieten getestet wurden und häufig unzureichend validiert wurden (Hecht 2013). Auch ist festzuhalten, dass wissensbasierte Ansätze nur schwer adaptier-

bar sind, wie etwa das im SEMENTA® implementierte Regelwerk (Meinel et al. 2008). Zielführender wäre deshalb eine Klassifizierung mithilfe eines datengetriebenen Ansatzes unter Nutzung von Methoden des maschinellen Lernens. Die Mustererkennung und das Gebiet des maschinellen Lernens stellt dabei ein breites Spektrum an Methoden zur Verfügung, deren Einsatz für die automatische Klassifizierung von Gebäudegrundrissen bislang nur in wenigen Arbeiten systematisch untersucht wurde. Ziel der Dissertation von Hecht (2013) war deshalb die Entwicklung und Validierung geeigneter Methoden für die Gebäudeklassifizierung. In diesem Zusammenhang wurden auch Fragen zu den Datenanforderungen sowie zur Eignung aktuell verfügbarer Geobasisdaten, Fragen zur Ableitung relevanter Gebäudemerkmale und Fragen zur Klassifikationsgenauigkeit und ihre Einflussfaktoren erörtert.

3 Methodik

Für die automatische Interpretation wurde eine datengetriebene, überwachte Klassifikationsstrategie verfolgt, da die zu erkennenden Gebäudetypen als bekannt vorausgesetzt werden können. Die Methodik für die automatische Klassifizierung ist modular aufgebaut und in Abbildung 1 schematisch dargestellt. Nach Festlegung der Rahmenbedingungen (Definition der Gebäudetypologie und Eingangsdaten) werden die fünf zentralen methodischen Bausteine angewandt, die zusammen das Building Footprint Classification Tool (BFClassTool) bilden. Die Beschreibung der Gebäude erfolgt über geometrische, topologische, statistische und semantische Merkmale, die mit Methoden der digitalen Bildverarbeitung und der räumlichen Analyse berechnet werden können. Während der Klassifikatorentwicklung wurden 16 verschiedene überwachte Klassifikationsverfahren anhand ausgewählter Datensätze getestet und deren Generalisierungsfähigkeit mittels 10-facher Kreuzvalidierung geschätzt.

Zum Einsatz kamen klassische lineare Verfahren, Künstliche Neuronale Netze, Support Vector Machines, Entscheidungsbaumverfahren und Ensemble-Methoden. Der Ensemble-basierte Random-Forest-Algorithmus (Breiman 2001) zeigte die höchste Generalisierungsfähigkeit und Effizienz und wurde als bester Klassifikator im BFClassTool implementiert.

Am Ende erfolgt die Modellanwendung und -bewertung im Rahmen einer Genauigkeitsanalyse unter Berücksichtigung verschiedener Untersuchungsgebiete, Eingangsdaten und Trainingsdatenmengen. Betrachtet werden dabei sowohl die Gesamtgenauigkeit als auch klassenspezifische Gütemaße, wie die Herstellergenauigkeit (engl. Producer's Accuracy) und die Nutzergenauigkeit (engl. User's Accuracy) (Congalton, Green 1998), auf deren Grundlage eine Bewertung verschiedener Eingangsdaten möglich ist.

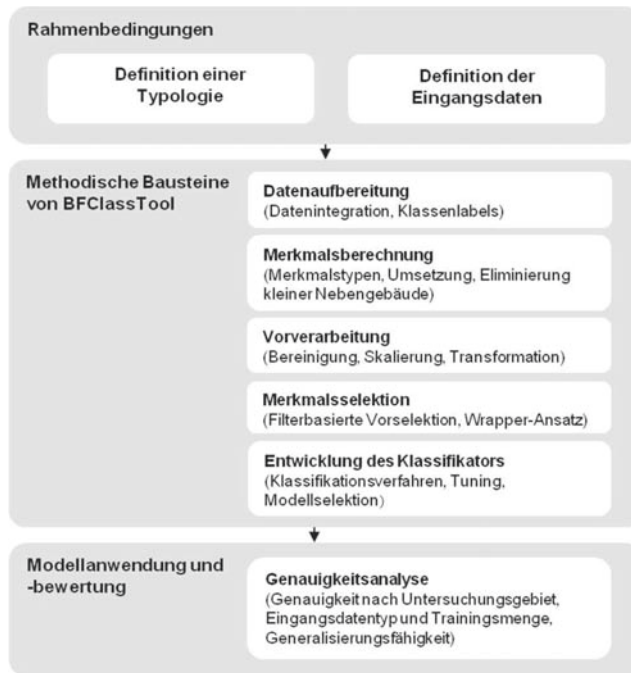


Abb. 1: Arbeitsschritte (Quelle: eigene Bearbeitung)

3.1 Gebäudetypologie

Die Gebäude sollen nach städtebaulichen Kriterien klassifiziert werden. Die entworfene Gebäudetypologie (vgl. Abb. 2) ist für eine breite Anwendung gedacht und orientiert sich im Wesentlichen an klassischen Gebäudetypologien des Städtebaus und der Wohnbauforschung (Müller, Korda 1999; IWU 2003; Buchert et al. 2004). Im Hinblick auf zu modellierende Zielgrößen der Siedlungsstruktur, wie z. B. die Geschossflächendichte, die Wohnungs- oder Einwohnerdichte, liegt der Fokus der Typologie auf der Wohnnutzung (11 Wohngebäudenutzung, 3 Nichtwohngebäudetypen). Eine detaillierte Beschreibung der einzelnen Typen ist in Hecht (2013) nachzulesen.

3.2 Eingangsdaten

Informationen zum Gebäudegrundriss sind in verschiedenen Geobasisdaten zu finden, wie etwa in digitalen topographischen Karten im Maßstab 1:25 000 (TK25, DTK25-V oder DTK25, im ATKIS Basis-DLM¹ (ATKIS), in der Automatisierten Liegenschaftskarte (ALK) beziehungsweise im amtlichen Liegenschaftskatasterinformationssystem (ALKIS) sowie in daraus abgeleiteten Produkten, wie den amtlichen Hausumringen (HU) und 3D-Gebäudemodellen. Weitere Information können den Dokumenten der AdV

¹ nur in einigen neuen Bundesländern

(www.adv-online.de) und der Zentralen Stelle für Hauskoordinaten, Hausumringe und 3D-Gebäudemodelle² (ZSHH) entnommen werden. Nutzergenerierte Daten, wie OpenStreetMap, enthalten zwar auch Gebäudegrundrisse, eine Nutzung dieser Daten macht aufgrund der Unvollständigkeit jedoch aktuell keinen Sinn (vgl. Kunze et al. 2013). Auch aus Fernerkundungsdaten abgeleitete Gebäudegrundrisse werden wegen der fehlenden Möglichkeit einer vollautomatischen Extraktion mit hinreichender Genauigkeit nicht weiter betrachtet.

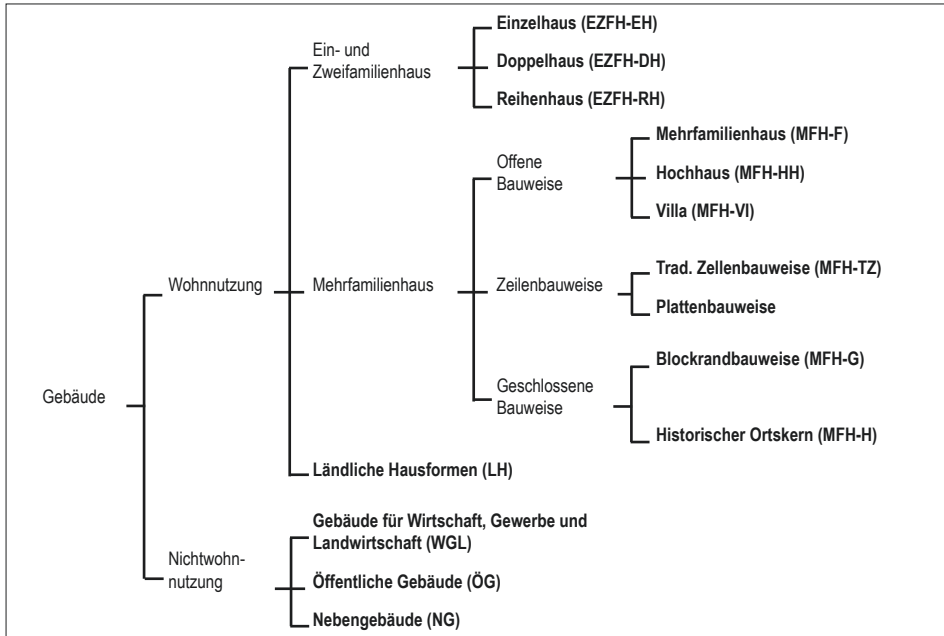


Abb. 2: Gebäudetypologie (Quelle: eigene Bearbeitung)

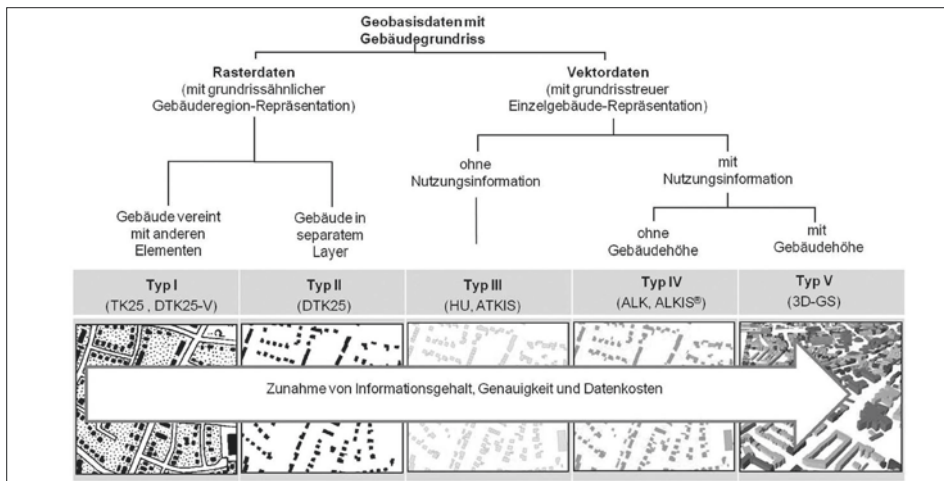


Abb. 3: Geobasisdaten mit Gebäudegrundrissinformation (Quelle: eigene Bearbeitung)

² www.bezreg-koeln.nrw.de/brk_internet/organisation/abteilung07/dezernat_74/zshh/index.html

Die betrachteten Geodatensätze lassen sich hinsichtlich der geometrischen Gebäudemodellierung und dem semantischen Informationsgehalt in fünf Eingangstypen unterscheiden (vgl. Abb. 3).

Als unterstützende Geometrie werden die Siedlungsblöcke und deren Flächennutzung aus dem ATKIS Basis-DLM sowie amtliche Hauskoordinaten hinzugezogen.

4 Ergebnisse

Nach einer Vorstellung der Untersuchungsgebiete und Daten sollen die wichtigsten Ergebnisse der Genauigkeitsuntersuchung im Vordergrund stehen.

4.1 Untersuchungsgebiete und Daten

Das entwickelte Klassifikationsverfahren wurde an verschiedenen Siedlungstypen der Bundesrepublik getestet. Die Auswahl der Untersuchungsgebiete erfolgte unter Berücksichtigung sowie der Verfügbarkeit der Geobasisdaten sowie einer ausreichend großen Menge an Referenzgebäuden.

Gewählt wurden die Städte Dresden, Halle und Krefeld, die Kleinstadt Stolpen sowie ländliche Gemeinden in Sachsen (Diera-Zehren, Crostwitz, Stolpen und Rechenberg-Bienenmühle). Der Aufbau der Referenzdatenbasis erfolgte unter Nutzung bereits vorhandener Kartierungen (Umkodierung, räumliche Zuordnung, Transformation etc.). Für die Untersuchungsgebiete wurden die Datengrundlagen zum Gebäudegrundriss (alle 5 Eingangstypen), dem Baublock und den Hauskoordinaten beschafft.

4.2 Klassifikationsgenauigkeit nach Eingangstyp

Die Gesamtgenauigkeit unter Nutzung von Random Forest wurde für jeden Datensatz über eine 10-fache Kreuzvalidierung bestimmt. Diese nimmt vom Eingangstyp I bis V zu (vgl. Abb. 4). So können beispielsweise 90 % bis 95 % aller vektorbasierten Gebäudegrundrisse (z. B. HU, ALK, 3D-Gebäude) und 76 % bis 88 % aller Gebäude aus topographischen Rasterkarten richtig klassifiziert werden. Die höchste Genauigkeit konnte für die 3D-Gebäudedaten von Krefeld erreicht werden. Bei ausreichend großer Trainingsdatenmenge wurde aber auch im städtischen Gebiet für die ALK-Gebäude eine Genauigkeit von über 94 % (Dresden, Krefeld) und für die Gebäude des Eingangstyps III (ATKIS) mindestens über 90 % (Dresden, Halle, Krefeld) gemessen. Für die Kleinstadt Stolpen und den dörflichen Gebieten wurde eine geringere Genauigkeit beobachtet, die jedoch teilweise im Zusammenhang mit der deutlich geringeren Anzahl an Trainingsobjekten steht.

		Untersuchungsgebiete				
		Stadt Dresden	Stadt Halle	Stadt Krefeld	Kleinstadt Stolpen	Dörfli. Gebiete
Eingangsdaten	Typ I DTK25-V	78,9 % (±0,67)	76,6 % (±1,27)	76,6 % (±6,91)	67,4 % (±11,46)	56,4 % (±7,04)
	Typ II DTK25		88,9 % (±0,44)	78,2 % (±2,16)		
	Typ III Hausumringe	90,4 % (±0,62)	91,8 % (±0,45)	93,6 % (±0,51)	72,2 % (±9,01)	62,4 % (±3,41)
	Typ IV ALK	94,3 % (±0,39)		94,3 % (±0,33)	84,2 % (±4,46)	78,7 % (±5,09)
	Typ V 3D-Gebäude			94,9 % (±0,28)		

Abb. 4: Gesamtgenauigkeit und Standardabweichung in Klammern aller betrachteten Datensätze ermittelt aus 10-facher Kreuzvalidierung. Einfärbung der Zellen von grün (sehr gut) über gelb (befriedigend) bis rot (mangelhaft) (Quelle: eigene Bearbeitung)

4.3 Klassenspezifische Genauigkeit

Die Betrachtung der Gesamtgenauigkeit ist allein nicht ausreichend, um die Qualität einer Klassifikation zu beurteilen. Darum wurden Konfusionsmatrizen durch Vergleich der klassifizierten Gebäudemenge mit den Referenzdaten abgeleitet anhand derer die Herstellergenauigkeit und Nutzergenauigkeit einzelner Klassen berechnet werden kann.

Für die städtischen Untersuchungsgebiete konnten bei Verwendung des Eingangsdatentyps III bis V für die Mehrheit der Klassen Herstellergenauigkeiten von über 90 % erzielt werden. Insbesondere die Klassen der Wohnbebauung MFH-G, MFH-TZ, MFH-IZ, EFZH-EH, EFZH-DH, EFZH-RH und die Nichtwohnnutzungsklassen WGL und ÖG können sehr gut vorhergesagt werden. Eine geringere Genauigkeit ist für die häufig unterbesetzten Klassen der freistehenden Mehrfamilienhäuser (MFH-F), Ländlichen Häuser (LH) und Hochhäuser (MFH-HH) zu beobachten. Bei der Verwendung von Gebäuden aus topographischen Karten (Eingangsdatentyp I und II) ist die Genauigkeit über alle Klassen hinweg deutlich geringer.

4.4 Diskussion

Den wichtigsten Einfluss auf die Klassifikationsgenauigkeit haben die verwendeten Datengrundlagen, da sich diese im Informationsgehalt und Generalisierungsgrad unterscheiden. Die Klassifikationsgenauigkeit erhöht sich dabei mit der zur Verfügung stehenden Information, die dem Klassifikator mittels numerischer Merkmale bereitgestellt werden können. Für alle drei städtischen Untersuchungsgebiete konnten ver-

gleichbare Genauigkeiten festgestellt werden. Bei Nutzung der ATKIS-Gebäude war die Genauigkeit beispielsweise 93,6 % (Krefeld), 91,8 % (Halle) und 90,4 % (Dresden) und für die DTK25-V 78,9 % (Dresden), 76,6 % (Krefeld) und 76,6 % (Halle). Es kann demnach vermutet werden, dass für andere deutsche Städte vergleichbare Genauigkeiten erzielt werden können, sofern für diese eine ausreichend große Trainingsdatenmenge zur Verfügung steht. Eine Variation der Trainingsdatenmenge zeigte, dass die Gesamtgenauigkeit mit dieser stetig zunimmt und gegen die Genauigkeit konvergiert, die bei theoretisch unendlicher Trainingsdatenmenge erreicht wird (Hecht 2013). Am Beispiel der ATKIS-Gebäude von Halle reichen beispielsweise 625 Objekte aus, um einen Klassifikator mit einer Genauigkeit von ca. 80 % zu trainieren. Stehen 2 500 Trainingsobjekte zur Verfügung, so können bereits über 85 % der Gebäude richtig klassifiziert werden. Bei Nutzung von 10 000 Trainingsobjekten wurde hingegen eine Genauigkeit von über 90 % erreicht.

Die Frage nach der Übertragbarkeit spielt in der Praxis eine bedeutende Rolle, da die Erhebung von Trainingsdaten in der Regel mit großem zeitlichem Aufwand, Expertise und hohen Kosten verbunden ist. In einer Untersuchung wurde deshalb die Übertragbarkeit eines erlernten Klassifikators erprobt. Die Experimente zeigen, dass eine Klassifizierung von Gebäudegrundrissen einer Stadt mit einem auf Grundlage einer anderen Stadt trainierten Klassifikator nur dann gut funktioniert, wenn die Städte durch ähnliche städtebauliche Muster der Bebauungsstruktur gekennzeichnet sind. Für eine deutschlandweite Anwendung des Verfahrens bedeutet es, dass eine regionale Differenzierung der Landesfläche und die Erhebung von Trainingsdaten in diesen Regionen nötig ist.

5 Fazit und Ausblick

Der aktuelle Forschungsstand belegt, dass nur wenige Arbeiten vorliegen, die den Einsatz von Verfahren der Mustererkennung und des maschinellen Lernens für die Gebäudeklassifikation verfolgen. Viele Ansätze stützen sich auf wissensbasierte Modelle, die wenig flexibel bzgl. einer Änderung der Datengrundlage oder der Gebäudezielklassen sind. Ferner fehlt es den meisten Ansätzen an einer kritischen Genauigkeitsbetrachtung unter Nutzung unabhängiger Testdaten. Deswegen wurde bei der Entwicklung eines Verfahrens zur automatischen Gebäudeklassifizierung besonderer Wert auf eine hohe Flexibilität, Automation sowie eine zuverlässige Validierung gelegt. Der entwickelte Ansatz beschränkt sich dabei auf die ausschließliche Nutzung von Geobasisdaten. Damit wird eine flächendeckende Anwendbarkeit des Verfahrens in Deutschland und Ländern mit vergleichbarer Datenlage abgesichert.

Die Ergebnisse zeigen, dass durch Kombination der räumlichen Analysen mit Methoden der Mustererkennung und des maschinellen Lernens eine automatische Klassifizierung der Gebäude mit einer Genauigkeit von über 90 % möglich ist. Dies eröffnet ein

breites Spektrum an Anwendungsszenarien (Quantitative Stadtforschung, Stadt- und Regionalplanung, Infrastrukturplanung, Geomarketing, Energiemodellierung, Risikoabschätzung, Monitoring etc.). Weitere Untersuchungen zur Anwendbarkeit auf andere Problemstellungen, Gebäudetypologien, Daten und Untersuchungsgebiete sind denkbar. Durch Berücksichtigung weiterer Daten (LoD2, Flurstücke, Bilddaten, semantische Information aus OSM, Firmendaten) könnte das Verfahren in Zukunft weiter optimiert werden. Ein weiterer Schritt wäre die Evaluierung des Verfahrens anhand projizierter sozioökonomischer Zielgrößen (z. B. Bevölkerung, Haushalte, Energieverbrauch etc.) mit Referenzdaten zur Abschätzung siedlungsstruktureller Kennzahlen.

Die Arbeit liefert einen wichtigen Beitrag zur Abschätzung kleinräumiger Indikatoren zur Siedlungsstruktur, die im Rahmen des „Monitors der Siedlungs- und Freiraumentwicklung“ (www.ioer-monitor.de) implementiert werden könnten. Es könnten damit weitaus differenziertere Informationen zur Geschossflächendichte, Gebäudevolumen, der Gebäudeoberfläche oder weiteren sozio-ökonomischen Kenngrößen abgeschätzt und bereitgestellt werden. Für eine flächendeckende Klassifizierung aller Gebäudegrundrisse sind jedoch noch geeignete Strategien zu erarbeiten, um regionale Unterschiede in der Bebauungsstruktur zu berücksichtigen.

6 Danksagung

Die vorgestellten Ergebnisse waren Gegenstand einer Promotion, die am Leibniz-Institut für ökologische Raumentwicklung (IÖR) bearbeitet und am Institut für Kartographie der TU Dresden verteidigt wurde. Alle genannten Geobasisdaten standen dem IÖR für Forschungszwecke zur Verfügung. Der Autor möchte sich beim Bundesamt für Kartographie und Geodäsie (BKG) und dem Staatsbetrieb Geobasisinformation und Vermessung Sachsen (GeoSN) für die Bereitstellung dieser Daten bedanken.

7 Literatur

- AdV – Arbeitsgemeinschaft der Vermessungsverwaltungen (2008): ALKIS-Objektartenkatalog – Version 6.0. (Stand: 11.04.2008) AdV (Dokumentation zur Modellierung der Geoinformationen des amtlichen Vermessungswesens).
- Barnsley, M. J.; Barr, S. L. (1996): Inferring urban land use from satellite sensor images using kernel-based spatial reclassification. In: Photogrammetric Engineering Remote Sensing. 62(8)/1996, 949-958.
- Behnisch, M.; Meinel, G.; Burckhardt, M.; Hecht, R. (2012): Auswertungen zum Gebäudebestand in Deutschland auf Grundlage digitaler Geobasisdaten. In: Meinel, G.; Schumacher, U.; Behnisch, M. (Hrsg.): Flächennutzungsmonitoring IV. Genauere Daten – informierte Akteure – praktisches Handeln. Berlin: Rhombos, IÖR Schriften 60, 151-158.

- Breiman, L. (2001): Random Forests. In: *Machine Learning*. 45(1)/2001, 5-32.
- Buchert, M.; Fritsche, U.; Jenseit, W.; Rausch, L.; Deilmann, C.; Schiller, G.; Siedentop S.; Lipkow, A. (2004): Nachhaltiges Bauen und Wohnen in Deutschland: Stoffflussbezogene Bausteine für ein nationales Konzept der nachhaltigen Entwicklung: UBA-FB 000543. (Forschungsbericht Nr. 01/2004) Umweltbundesamt (Reihe).
- Congalton, R. G.; Green, K. (1998): *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices*. 1. Aufl. CRC Press. ISBN: 0873719867.
- Geiß, C.; Taubenböck, H.; Wurm, M.; Esch, T.; Nast, M.; Schillings, C.; Blaschke, T. (2011): Remote Sensing-Based Characterization of Settlement Structures for Assessing Local Potential of District Heat. In: *Remote Sensing*. 3(7)/2011, 1447-1471.
- Gong, P.; Howarth, P. F. (1992): Frequency-Based Contextual Classification and Gray-Level Vector Reduction for Land-Use Identification. In: *Photogrammetric Engineering and Remote Sensing*. 58(4)/1992, 423-437.
- Haußmann, M. (2012): Probleme und Lösungen auf dem Weg zu kleinräumigen innerstädtischen Statistiken. In: Meinel, G.; Schumacher, U.; Behnisch, M. (Hrsg.): *Flächennutzungsmonitoring IV. Genauere Daten – informierte Akteure – praktisches Handeln*. Berlin: Rhombos, IÖR Schriften 60, 169-174.
- Hecht, R. (2013): *Automatische Klassifizierung von Gebäudegrundrissen – Ein Beitrag zur kleinräumigen Beschreibung der Siedlungsstruktur*. Dissertation, Technische Universität Dresden.
- Henn, A.; Römer, C.; Gröger, G.; Plümer, L. (2012): Automatic classification of building types in 3D city models Using SVMs for semantic enrichment of low resolution building data. In: *GeoInformatica*. 16(2)/2012, 281-306.
- IWU – Institut Wohnen und Umwelt (2003): *Deutsche Gebäudetypologie – Systematik und Datensätze*. Institut Wohnen und Umwelt GmbH.
- Kunze, C.; Hecht, R.; Hahmann, S. (2013): „Zur Vollständigkeit des Gebäudedatenbestandes von OpenStreetMap“. In: *Kartographische Nachrichten*. 63(2-3)/2013, 73-81.
- Lüscher, P.; Weibel, R.; Burghardt, D. (2009): Integrating ontological modelling and Bayesian inference for pattern classification in topographic vector data. In: *Computers, Environment and Urban Systems*. 33(5)/2009, 363-374.
- Meinel, G.; Hecht, R.; Herold, H. (2009): Analyzing building stock using topographic maps and GIS. In: *Building Research & Information*. 37(5-6)/2009, 468-482.
- Meinel, G.; Hecht, R.; Herold, H.; Schiller, G. (2008): Automatische Ableitung von stadtstrukturellen Grundlagendaten und Integration in einem Geographischen Informationssystem. *Forschungen*, Heft 134, BMVBS/BBR (Hrsg.), Bonn.
- Müller, W.; Korda, M. (1999): *Städtebau*. 4. neubearbeitete Auflage. Stuttgart, Leipzig: Teubner Verlag.
- Neidhart, H.; Sester, M. (2004): Identifying Building Types and Building Clusters Using 3D-Laser Scanning and GIS-Data. In: *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*. Istanbul.

- Orford, S.; Radcliffe, J. (2007): Modelling UK residential dwelling types using OS Mastermap data: A comparison to the 2001 census. In: *Computers, Environment and Urban Systems*. 31 (2), 206-227.
- Römer, C.; Plümer, L. (2010): Identifying Architectural Style in 3D City Models with Support Vector Machines. In: *Photogrammetrie – Fernerkundung – Geoinformation*. 2010, 371-384.
- Smith, D.; Crooks, A. (2010): From buildings to cities: techniques for the multi-scale analysis of urban form and function. Working Paper Series, Nr. 155, University College London.
- Steiniger, S.; Lange, T.; Burghardt, D.; Weibel, R. (2008): An Approach for the Classification of Urban Building Structures Based on Discriminant Analysis Techniques. In: *Transactions in GIS*. 12(1)/2008, 31-59.
- Werder, S.; Kieler, B.; Sester, M. (2010): Semi-automatic interpretation of buildings and settlement areas in user-generated spatial data. In: *Proceedings of the 18th SIGSPATIAL International Conference on Advances in Geographic Information Systems*. New York, NY, USA: ACM (GIS '10), 330-339.
- Westenberg, G.; Will, K. (2013): Geometrieinformationen zum Gebäudebestand – die Produkte Hauskoordinaten, Hausumringe und 3D-Gebäudemodelle. *Flächennutzungsmonitoring V. Methodik – Analyseergebnisse – Flächenmanagement*. Berlin: Rhombos, IÖR Schriften 61, 147-154.
- Wharton, S. W. (1982): A contextual classification method for recognizing land use patterns in high resolution remotely sensed data. In: *Pattern Recognition*. 15(4)/1982, 317-324.